

# 유비쿼터스 컴퓨팅 환경에서 컨텍스트 예측을 위한 시계열 분석 기반 사용자 모델링

## User Modeling based Time-Series Analysis for Context Prediction in Ubiquitous Computing Environment

최영환\* · 이상용\*\*

Young-Hwan Choi\* and Sang-Yong Lee\*\*+

\* 공주대학교 컴퓨터공학과

\*\* 공주대학교 컴퓨터공학부

### 요 약

기존의 예측 알고리즘들은 실시간 환경에서 학습 데이터 처리에서 오는 시간지연 문제, 구현의 어려움 등으로 개인화된 실시간 서비스를 제공하는 컨텍스트 인식 환경에서 사용하기에 적합하지 않다. 본 논문에서는 사용자 모델을 이용하여 컨텍스트 예측 알고리즘의 처리시간 단축과 예측 정확도를 향상시키기 위한 연구를 제안한다. 컨텍스트 예측을 위하여 사용자의 컨텍스트 중에서 이동경로를 사용한다. 이동경로를 기반으로 시계열 분석 방법을 통하여 사용자 모델을 생성하고, 생성된 사용자 모델을 시퀀스 매칭 방법을 이용하여 사용자의 컨텍스트를 예측한다. 기존 예측 알고리즘과 본 연구에서 제안한 예측 알고리즘을 시뮬레이션을 통하여 처리시간 및 예측 정확도를 비교한 결과, 실시간 서비스 환경에서 예측 정확도는 기존 예측 알고리즘들과 비슷한 결과를 보였고, 처리시간은 사용자 모델을 사용한 경우가 시퀀스 매칭을 사용한 경우보다 평균 40% 정도 감소시킬 수 있음을 알 수 있었다.

**키워드** : 컨텍스트 인식, 컨텍스트 예측, 사용자 모델링, 시계열 분석

### Abstract

The context prediction algorithms are not suitable to provide real-time personalized service for users in context-awareness environment. The algorithms have problems like time delay in training data processing and the difficulties of implementation in real-time environment. In this paper, we propose a prediction algorithm with user modeling to shorten of processing time and to improve the prediction accuracy in the context prediction algorithm. The algorithm uses moving path of user contexts for context prediction and generates user model by time-series analysis of user's moving path. And that predicts the user context with the user model by sequence matching method. We compared our algorithms with the prediction algorithms by processing time and prediction accuracy. As the result, the prediction accuracy of our algorithm is similar to the prediction algorithms, and processing time is reduced by 40% in real time service environment.

**Key Words** : Context Awareness, Context Prediction, User Modeling, Time-Series Analysis

## 1. 서 론

최근 다양한 유비쿼터스 컴퓨팅 시스템들이 등장하여 실시간으로 개인화된 서비스를 제공하려 하고 있다. 유비쿼터스 환경에서 상황에 적합한 맞춤형 서비스를 제공하기 위해서는 동적으로 변화하는 컨텍스트 정보를 이용하여 사용자의 상황을 정확하게 파악해야 하며, 이를 위해서는 컨텍스트 예측 기술이 필수적이다.

컨텍스트 예측 기술은 유비쿼터스 환경에서 생성되는 다양한 컨텍스트 정보들을 이용하여 상황에 맞는 최적의 서비스를 실시간으로 제공하는데 목적이 있다. 이를 위하여 먼저 사용자의 컨텍스트를 인식하고 인식된 컨텍스트 정보들

로 사용자 프로파일을 구성한다. 그리고 구성된 프로파일을 여러 기법을 통해 개인의 성향이나 선호도를 분석하여 사용자의 미래의 컨텍스트를 예측하고 proactive한 서비스를 제공하게 된다.

기존에도 Markov Chains, Neural Networks, Bayesian Networks 등과 같은 학습을 통한 예측 알고리즘들이 존재하였지만 실시간 컨텍스트 인식이라는 특수한 환경에서는 사용할 수 없었다. 그리고 컨텍스트 인식 환경에서 사용하기 위해 개발된 알고리즘들도 구현상의 어려움이나 처리시간의 비효율성 등으로 인한 문제점들을 가지고 있으며, 이러한 문제점은 기존의 예측 알고리즘에도 해당한다.

본 논문에서는 기존의 예측 알고리즘들과는 다른 접근 방식을 통해 사용자의 컨텍스트 데이터 중 이동경로를 이용하고, 이를 시계열 분석 기반 사용자 모델링과 컨텍스트 데이터의 전처리를 통하여 컨텍스트 예측 알고리즘의 처리시간을 감소시키기 위한 기법을 제안한다.

접수일자 : 2009년 6월 27일

완료일자 : 2009년 9월 20일

+ 교신저자

## 2. 관련연구

### 2.1 컨텍스트 예측 프로젝트

컨텍스트의 예측은 컨텍스트 인식 환경에서 최적화된 서비스를 하기 위해 필수적인 기술이며 현재 많은 프로젝트에서 개발되었다.

Adaptive House Project[1]에서는 일반 가정에서 사용자들의 생활 패턴이나 습관 등을 시스템이 학습하여 이를 토대로 거주자들에 의해서 어떠한 일이 발생할 것인지를 예측하였다. Mayrhofer[2]는 사용자 컨텍스트 인식과 예측을 결합한 구조를 이용하여 사용자의 컨텍스트 정보를 축적하고 이를 통해서 다음 행동을 예측하였다.

Smart Doorplate Project[3]에서는 스마트 빌딩이 사용자의 부재시 예상 위치를 판단하여 부재중에 전화가 걸려온 경우 이를 사용자가 도착할 것으로 예상되는 목적지로 연결시켜 주는 작업을 수행하였다. Sigg[4]는 “A Novel Approach to Context Prediction in UBIComp Environment”에서 컨텍스트 예측의 정확도를 높이기 위해 컨텍스트 히스토리에 대한 시계열 로컬 정렬 기술에 관한 연구를 수행하였다.

특히, 유비쿼터스 환경에서 위치 정보는 사용자의 상태를 예측하여 이에 맞는 서비스를 제공하기 위한 중요한 정보이기 때문에 이를 활용하기 위한 연구가 중요하다. 위치정보는 사용자의 다음 위치를 예측하는데 사용되며, 사용자의 다음 위치를 예측하는 것은 사용자에게 필요한 서비스를 효율적으로 제공하는데 매우 유용하게 활용될 수 있다.

Patterson[5] 등은 이를 위해 GPS 신호로 사용자 위치를 추적하고, 베이직안 네트워크로 GPS 신호를 모델링 하여 현재 사용자가 이용하고 있는 이동수단을 예측하는 방법을 제안하였다. Ashbrook[6] 등은 GPS 데이터를 k-means 알고리즘을 사용해 클러스터링 하여 사용자가 오래 머무르는 유효한 위치를 찾아내고, 이 위치간의 이동을 마코프 모델을 사용하여 모델링 하여 사용자 위치를 예측하도록 하였다. 하지만 사용자가 머무르는 위치만을 사용하기 때문에 이동 중 경로에 따른 예측은 불가능하며, 매우 결정적이기 때문에 예측하는데 있어 유연성이 떨어지는 단점이 있다.

### 2.2 기존의 예측 알고리즘

본 절에서는 일반적으로 사용되는 예측 알고리즘들의 특징과 문제점들을 살펴본다.

Markov Process[7]는 Markov 해석을 이용한 예측 알고리즘은 기본적으로 과거의 데이터를 기반으로 다음 사건의 발생 경향을 확률적으로 분석해 예측을 시도하며, 주로 서로 의존적인 일련의 사건들을 해석하는데 사용된다. Neural Network[8]은 신경회로망 중에서 가장 널리 사용되는 것은 다층 퍼셉트론(Multi Layer Perceptron, MLP)으로서 RBF(Radial Basis Function) 네트워크와 함께 대표적인 정적 신경망으로써 교사 학습(supervised learning)에 의한 인식 및 분류, 함수 근사화 등에 사용된다. Bayesian Networks[9]은 그래프 모델 중에서 방향성 비순환 그래프(Directed Acyclic Graph, DAG)에 기반을 둔 확률적 모델로 확률분포에 장점을 가지고 있지만 시계열 모델이나 대용량 데이터에서는 성능이 떨어지는 단점이 있다.

이러한 기존의 예측 알고리즘은 알고리즘 적용시 컨텍스트 정보와의 부합성(compatibility) 문제가 발생하며, 컨텍스트 인식 환경에서 생성되는 컨텍스트 데이터의 양이 방대

하기 때문에 실제로 시스템을 구현하는 것이 쉽지 않다. 또한 학습에 의해서 알고리즘을 처리하기 때문에 실시간 환경에서 트레이닝 데이터 처리에서 오는 시간지연 문제로 서비스의 적시성 문제가 발생할 수 있어 사용하기 적합하지 않다.

### 2.3 컨텍스트 인식 환경에서의 예측 알고리즘

컨텍스트 인식 환경에서 사용된 예측 알고리즘들은 다음과 같다.

Sequential Pattern Matching[10]은 사용자의 최근 상황 정보 시퀀스를 수집된 과거 상황정보 히스토리의 모든 시퀀스와 매칭을 시도하는데 시퀀스의 크기에 따라 상황정보의 예측정확도가 달라진다. 기존의 예측 알고리즘에 비해 실행속도가 다소 향상되었으나 하나의 컨텍스트 정보를 예측하기 위해 예측 요청이 올 때마다 데이터베이스의 처음부터 순차적 매칭을 수행하기 때문에 실시간 시스템의 처리시간 측면에서 비효율적이다.

Semantic Caching[11]은 FAR(Furthest away Replacement) 알고리즘을 사용하며 운영체제의 페이지 캐시 기법을 이용한 위치 인식 기반 캐싱 기법으로 위치 정보를 데이터에 추가함으로써 현재의 위치에서 가장 먼 위치 정보를 갖는 데이터를 교체의 대상으로 선택하게 된다. Page Cache 기법을 사용함으로써 가장 최근에 사용한 데이터의 재사용 빈도가 낮음에도 불구하고 Page Cache에 남아 있게 되고, 사용 빈도가 높은 데이터가 Cache에 없어서 다시 파일 시스템으로부터 불러와야 하는 경우가 발생하기 때문에 프로그램의 응답 속도가 느려지게 되는 문제점이 발생하고, 컨텍스트 인식 환경에서의 데이터 접근 패턴에 대응하지 못하기 때문에 각 데이터 단위마다 위치 정보를 불러야 하고 이를 검색해야 하는 부담이 발생한다.

Context-Aware Replacement 알고리즘[12]은 웨어러블 컴퓨터에서 페이지 캐시의 성능을 향상시키는 연구를 수행하여 순차접근의 경우 약 70%, 임의 접근의 경우 약 19% 가량의 성능향상을 얻을 수 있음을 보였다.

본 논문에서는 컨텍스트 인식환경이 달라 직접적인 비교는 어렵지만, 기존 예측 알고리즘의 예측 정확도를 유지할 수 있을과 처리시간에서의 성능 향상을 시뮬레이션을 통하여 보여준다.

## 3. 시계열 분석을 이용한 사용자 모델링

A. K. Dey[13]는 컨텍스트 데이터를 소스로부터 얻어진 Raw data, 컨텍스트의 의미를 표현한 Low-level 컨텍스트, 사용자의 의도가 표현된 High-level 컨텍스트로 분류하였으며, 표 1은 분류 예를 보여준다.

표 1. 컨텍스트 데이터의 분류.

Table 1. Classification of context data.

High-level context	Low-level context	Raw data	Context source
walking	14°C	001001111	thermometer
watching movie	64dB	109	microphone
writing	z	0x79	keyboard

### 3.1 컨텍스트 데이터 전처리

컨텍스트 데이터의 전처리는 Low-level 컨텍스트로부터 High-level 컨텍스트를 생성하는 과정이라고 볼 수 있다. 실시간으로 다양한 센서에서 입력되는 컨텍스트 데이터들을 예측 알고리즘에 사용하기에는 계산시간이 너무 오래 걸리고 noise들이 있어, noise를 제거하고 컨텍스트 데이터의 계산 시간을 단축하기 위한 전처리 과정이 필요하다.

본 논문에서는 컨텍스트 예측을 위해 위치 정보와 시간 정보를 사용한다. 사용자의 위치는 시간에 따라 값들이 변하는 일종의 시계열 함수(time-series function)라 할 수 있으므로 위치 정보와 시간 정보를 이용하여 사용자의 이동경로를 생성할 수 있다.

표 2에서는 컨텍스트 데이터 중 noise를 제거하고 위치 정보와 시간 정보를 이용하여 시간의 흐름에 따라 사용자의 이동경로를 시퀀스로 생성하는 과정을 보여준다.

표 2. 컨텍스트 데이터의 전처리.  
Table 2. Preprocessing of context data.

```
BEGIN
  UA : user A
  LAi : resent location of User A(i=0 to n)
  TLi : input time at LAi
  T : a fixed time interval
  HA={LAi, ..., LAn} : a time ordered path history
  SA : a set of Sequence LAi to LAj

  FOR each UA do
    FOR i = 0 to n
      LAi input HA
      IF (TLi - TLi+1) < T THEN
        IF (date of TLi == date of TLi+1) THEN
          LAi input SA
        ELSE IF
          create new SA and LAi input new SA
        ENDIF
      ENDIF
    ENDFOR
  ENDFOR
END
```

위 과정을 거쳐 생성된 사용자의 시퀀스들은 사용자 모델링 과정을 위해 각 사용자의 이동 시퀀스로 DB에 저장한다.

### 3.2 사용자 모델링

사용자 모델링 과정은 전처리 과정을 거친 각 사용자의 High-level 컨텍스트에 시간, 위치에서의 행동 등의 정보를 이용하여 사용자의 의도를 파악할 수 있도록 사용자 모델을 생성하게 된다. 이렇게 구축된 사용자 모델을 분석하여 사용자가 주기적으로 행하는 특정한 행동, 특정한 위치에서의 행동 등을 파악할 수 있다.

다음 표 3은 사용자 모델 객체를 보여준다.

표 3. 사용자 모델 객체.  
Table 3. Object of user model.

```
typedef struct_profile {
  int pro_type;
  union_proData {
    identify_info id_pro; // 사용자 ID
    day_info day_pro; // 날짜 정보
    intime_info in_pro; // 이동 시작 시간
    outtime_info out_pro; // 이동 종료 시간
    staytime_info stay_pro; // 이동 시간
    path_info path_pro[20]; // 이동 경로
    intention_info int_pro; // 이동 목적
  } data;
} profile_object
```

사용자의 위치 예측을 위하여 시간 간격을 바탕으로 사용자의 이동 패턴을 이산 시계열(discrete time series)과 연속 시계열(continuous time series)로 구분한다.

이산 시계열은 사용자의 이동시간 컨텍스트 중에서 특정한 간격을 가지는 이산 간격 즉, 사용자가 연속적으로 이동하는 패턴과 패턴 사이의 특정한 간격을 의미한다.

이렇게 분석된 이산 시계열을 기반으로 이산 간격과 이산 간격이 나타나는 구역을 사용자의 독립된 이동 시퀀스로 하고, 이동 시퀀스는 해당 시간동안 이동한 연속 시계열을 포함한다.

예측 알고리즘의 처리시간을 단축하기 위해 가장 최근의 의도가 표현된 사용자 모델과 빈번하게 주기적으로 나타나는 사용자 모델을 대표 컨텍스트로 두고 위치 예측시 새롭게 생성되는 사용자 컨텍스트와 우선 비교한다. 가능성이 가장 높은 컨텍스트와 비교함으로써 비교 횟수를 줄여 컨텍스트 예측 알고리즘의 수행시간을 단축할 수 있게 된다.

다음 표 4는 사용자 컨텍스트 예측에서의 시퀀스 매치를 위한 방법을 보여준다.

표 4. 시퀀스 매치  
Table 4. Sequential matching.

```
BEGIN
  Input pre_data[], i, j, context_count,
  seq_match, context-history size
  Generate context-history
  FOR j=0 to (context-history size) DO
    initialize each context information
    FOR I=0 to ( context-history size ) DO
      IF (context[i] == pre_data[i]) &&
        (context[i+1] == pre_data[i+1]) THEN
        Increase seq_match by 1
      ENDIF
    ENDFOR
    IF (context-history >= 1) THEN
      Increase context_count by 1
      Reset context_count
    ELSE
      Do original matching
    ENDIF
  ENDFOR
END
```

다음 표 5는 사용자 모델링 과정을 통해 생성된 사용자 모델의 예를 보여준다.

표 5. 사용자 모델.  
Table 5. User model.

컨텍스트 항목	컨텍스트 내용
날짜	2003.10.28
이동 시작 시간	14:13:58
이동 종료 시간	14:14:40
이동 시간	42 sec
이동 경로	i-b-i
이동 목적	printing

다음 그림 1은 사용자 컨텍스트로부터 사용자 모델을 생성하는 과정을 보여준다.

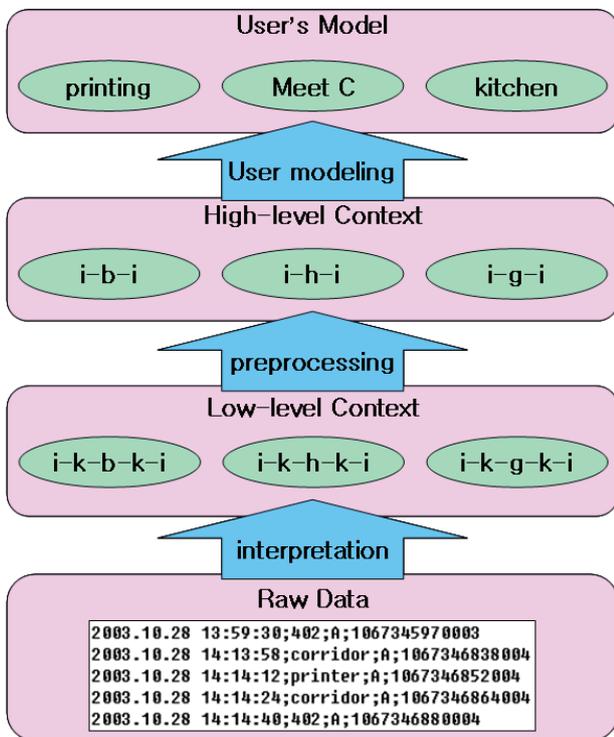


그림 1. 사용자 모델의 생성과정.  
Fig. 1. Generation process of user model.

#### 4. 실험 및 평가

본 논문에서 제안한 시계열 분석 기반 사용자 모델링 기법의 성능을 평가하기 위해서는 시뮬레이션을 수행할 데이터가 필요하다. 특히 컨텍스트 인식 환경에서는 센서 네트워크의 구축을 통한 사용자 컨텍스트 데이터를 기반으로 예측하는 것이 가장 이상적일 것이다. 하지만 위와 같은 실제 컨텍스트 인식환경을 구축하기 어렵기 때문에, 본 논문에서는 독일의 Augsburg 대학에서 실제 구축한 컨텍스트 인식

환경 기반의 공개된 컨텍스트 필드데이터(Augsburg Indoor Location Tracking Benchmarks : AILTB)[14]를 사용하여 제안한 기법의 성능 평가를 시뮬레이션을 통해 수행하였다.

AILTB 컨텍스트 데이터는 네 명의 연구원에 의해 여름과 가을 두 차례에 걸쳐 생성하였고, 그림 2와 같이 날짜, 시간, 섹터, 사용자, 시간스탬프의 포맷으로 이루어져 있다. 그림 3은 위치와 위치정보를 나타낸다.

AILTB는 가을에 수행한 실험 데이터의 수가 여름보다 많기 때문에 본 논문에서는 가을의 데이터를 트레이닝 데이터로 여름의 데이터를 테스트 데이터로 하여 시뮬레이션을 수행하였다.

```

2003.10.28 13:59:30;402;A;1067345970003
2003.10.28 14:13:58;corridor;A;1067346838004
2003.10.28 14:14:12;printer;A;1067346852004
2003.10.28 14:14:24;corridor;A;1067346864004
2003.10.28 14:14:40;402;A;1067346880004
    
```

그림 2. AILTB 데이터의 구조.  
Fig. 2. Structure of AILTB.

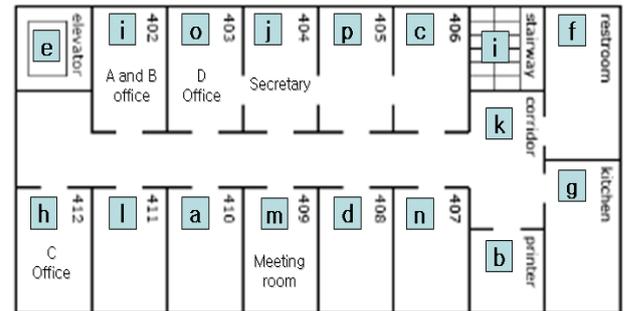


그림 3. 섹터와 섹터정보.  
Fig. 3. Sector and sector information.

제안한 방법에 대한 성능 평가는 두 가지 측면에서 수행하였다. 첫 번째는 제안된 방법과 기존 알고리즘과의 예측 정확도 면에서 비교 평가하였다.

표 6은 제안된 사용자 모델을 이용한 방법과 J. Petzold[3]가 평가한 기존 알고리즘의 예측정확도 측면에서의 성능평가 결과를 보여준다. 제안된 방법은 동일한 조건 하에서 기존의 예측 알고리즘과 거의 비슷한 성능을 가짐을 보여준다.

표 6. 알고리즘들의 예측 정확도 비교(단위 : %).

Table 6. Prediction accuracy comparison of algorithms.

User	Prediction Algorithm				
	MLP	BN	MP	SM	User Modeling
A	87.39	85.58	90.18	85.23	84.04
B	75.66	86.54	78.97	83.73	82.48
C	68.68	86.77	75.17	75.39	77.65
D	74.06	69.78	78.05	82.45	81.46
Ave	76.45	82.17	80.59	81.70	81.41

두 번째는 시퀀스 매칭 방법과의 수행시간에 대한 비교 평가이다. 기존의 예측 알고리즘들은 실시간 환경에서 사용하기 어려워 직접적인 수행시간 평가가 불가능하기 때문에 컨텍스트 인식 환경에서 주로 사용되는 시퀀스 매칭 방법과 비교 평가하였다.

표 7에서는 각 사용자에 대한 수행시간을 비교한 결과이며, 시퀀스 매칭을 사용한 경우보다 사용자 모델을 사용한 경우가 평균 40%정도 수행시간이 감소한 것을 볼 수 있다.

표 7. 각 사용자들에 대한 수행시간 (단위 : usec).  
Table 7. Processing time of each users.

Method	User				
	A	B	C	D	Ave
Sequential Matching	694.2	2258.6	1875.5	1298.8	1531.8
User Modeling	566.3	1095.2	1175.8	857.4	923.7

사용자 모델에 저장된 사용자의 시퀀스는 주기적으로 업데이트가 필요하다. 이는 시간이 지남에 따라 사용자들의 행동양식이나 습관이 바뀔 수 있기 때문이다. 만약 업데이트가 이뤄지지 않는다면 잘못된 시퀀스를 참조하게 함으로써 예측 오류를 일으키게 된다.

예측 오류를 막기 위한 방법으로 Event-Driven 방식과 Time-Driven 방식을 병행하여 사용한다.

Event-Driven 업데이트는 사용자의 예기치 못한 행동양식 변화로 인해 예측하고자 하는 시퀀스 정보의 매치를 대표 사용자 모델에서 찾을 수 없을 때 이를 DB에서 찾아 수정된 시퀀스 정보를 사용자 모델에 저장하는 방법이다.

Time-Driven 업데이트는 시스템의 매치 탐색 요청이 없어도 주기적인 DB의 업데이트를 통해 새로운 상황정보나 수정된 상황정보를 사용자 모델에 업데이트 하는 방법이다.

### 5. 결론

본 논문에서는 사용자의 컨텍스트 데이터 중 이동경로를 시계열 분석 기반 사용자 모델링과 컨텍스트 데이터의 전처리를 통하여 컨텍스트 예측 알고리즘의 처리시간을 감소시키기 위한 기법에 대한 연구를 수행하였다.

컨텍스트 예측 시 가장 최근의 사용자 모델과, 주기적으로 나타나는 사용자 모델을 대표 컨텍스트로 두고 새롭게 생성되는 사용자 컨텍스트와 우선 비교하도록 하여 가능성이 가장 높은 컨텍스트와 비교함으로써 비교횟수를 줄일 수 있었다. 실험결과를 통해 본 연구에서 제안한 컨텍스트 예측 알고리즘은 실시간 서비스 환경에서 컨텍스트 예측 알고리즘 수행 시 기존의 예측 알고리즘들과 비슷하게 예측 정확도를 유지한 채 처리시간을 약 40% 정도 감소시킬 수 있음을 보여주었다.

본 논문에서는 사용자의 컨텍스트 중 위치 데이터를 기반으로 예측 알고리즘을 수행하였다. 향후 시간 예측이 추가된 예측 알고리즘에 관한 연구를 진행할 예정이다.

### 참 고 문 헌

- [1] M. C. Mozer, "The Neural Network House: An Environment that adapts to its Inhabitants," in *AAAI Spring Symposium on Intelligent Environments*, pp. 110-114, 1998.
- [2] R. Mayrhofer, "An Architecture for Context Prediction," *Trauner Verlag, Schriften der Johannes-Kepler-Universität Linz*, volume C45, 2005.
- [3] J. Petzold, F. Bagci, W. Trumler and T. Ungerer, "Next Location Prediction within a Smart Office Building," In *Proc. of 1st International Workshop on Exploiting Context Histories in Smart Environments at the 3rd International Conference on Pervasive Computing*, 2005.
- [4] S. Sigg, S. Haseloff, K. David, "A Novel Approach to Context Prediction in Ubicomp Environments," *The 17th Annual IEEE International Symposium on Personal, Indoor and Mobile Radio Communications*, 2006.
- [5] D. Patterson, L. Liao, D. Fox, and H. Kautz, "Inferring High-Level Behavior from Low-Level Sensors," *Proc. of the Fifth International Conference on Ubiquitous Computing*, pp. 73-89, Seattle, WA, October, 2003.
- [6] D. Ashbrook and T. Starner, "Learning Significant Locations and Predicting User Movement with GPS," *Proc. of IEEE Sixth Int. Symp. on Wearable Computing*, Seattle, WA, October, 2002.
- [7] E. Behrends, "Introduction to Markov Chains," *Advanced Lectures in Mathematics Vieweg*, 1999
- [8] K. Gurney, *An Introduction to Neural Networks*, Routledge, 2002.
- [9] F. V. Jensen, *An Introduction to Bayesian Networks*, UCL Press, 1996.
- [10] V. Guralnik, K. Z. HAIGH, "Learning Models of Human Behaviour with Sequential Patterns," *AAAI Workshop on Automation as Caregiver*, pp. 24-30, July 2002.
- [11] Q. Ren, M. H. Dunham, "Using Semantic Caching to Manage Location Dependent Data in Mobile Computing," In *Proc. of the International Conference on Mobile Computing and Networking*, pp. 210-221, 2000.
- [12] 황우민, 임상석, 박규호, "웨어러블 컴퓨터를 위한 사용자 컨텍스트 인식 페이지 캐시," *한국차세대PC 학회논문지*, Vol.2, No.1, pp.46-55. March, 2006.
- [13] A. K. Dey, "Providing architectural support for building context-aware applications," *PhD thesis, Georgia Institute of Technology*, 2000.
- [14] J. Petzold, "Augsburg Indoor Location Tracking Benchmarks," *Institute of Computer Science University of Augsburg Germany*, April 2004.

저 자 소 개



**최영환(Young-Hwan Choi)**

1999년 : 공주대학교 전자계산학과(학사)  
2001년 : 공주대학교 대학원 전자계산학과  
(이학석사)  
2001년~현재 : 공주대학교 대학원 컴퓨터  
공학과 박사과정 수료

관심분야 : 인공지능, 유비쿼터스 컴퓨팅, 컨텍스트 예측,  
개인화서비스 등  
E-mail : cyhmad@kongju.ac.kr



**이상용(Sang-Yong Lee)**

1984년 : 중앙대학교 전자계산학과(공학사)  
1988년 : 일본동경대학대학원 총합이공학  
연구과(공학석사)  
1988년~1989년 : 일본 NEC 중앙연구소  
연구원  
1993년 : 중앙대학교 일반대학원 전자계산  
학과(공학박사)

1996년~1997년 : University of Central Florida 방문교수  
1993년~현재 : 공주대학교 컴퓨터공학부 교수

관심분야 : 인공지능, 컨텍스트 예측, 컴퓨터게임 등  
E-mail : sylee@kongju.ac.kr